01｜动态数组：按需分配的vector为什么要二倍扩容？

2021-12-11 黄清昊

《算法实战高手课》 课程介绍 >

讲述：黄清昊
时长 19:01　大小 17.43M

你好，我是微扰君。今天我们进入第一章基础数据结构的学习。

计算机程序一直以来最根本的作用就是处理数据。即使在早期的计算机中，计算就已经不仅仅是几个数字之间的加减乘除那么简单了，经常需要处理大量线性存储的数据，一个很好的例子就是向量乘法。显然，我们需要找到一种合适的方式在计算机中存储这些信息，并能让我们可以快速地进行向量运算。

再举一个更工程化的例子。假设有个需求，我们希望只借助内存实现一个简易的银行账户管理系统，每个账号里包括两个基本信息：账户 ID 及余额。用户首次开户的时候，会分配一个账户 ID；系统要支持用户通过 ID 快速查询余额，也可以存款 / 取款改变自己的余额。

你可能会觉得这有什么难的？用数组就可以解决。建立一个整型动态数组，每来一个用户就给存到数组的某个位置，用该位置的数组下标来当用户的 ID 就行。查询起来更快，数组大小是动态的，也不用考虑用户数量超过容量上限的问题。

但是，**基于下标随机访问数组元素为什么这么高效？动态数组是怎么做到看起来可以有无限容量？扩容机制的时间复杂度是多少，是不是会带来额外的内存浪费呢**？不知道你有没有思考过这些问题。

今天，我们就带着这些问题一起学习第一种序列式容器 vector，也就是动态数组。相信你学完之后，对这些问题的理解就深刻啦。

数组和内存

讲解动态数组的实现之前，首先要回顾一下数组是什么，不过为了和动态数组区分开来，我们常常也称之为静态数组。可以这样定义：静态数组是由相同类型的元素线性排列的数据结构，在计算机上会分配一段连续的内存，对元素进行顺序存储。

其中有三个关键词，**相同类型、连续内存、顺序存储**。之所以这样设计，本质就是为了能做到基于下标，对数组进行 O(1) 时间复杂度的快速随机访问。

存储数组时，会事先分配一段连续的内存空间，将数组元素依次存入内存。因为数组元素的类型都是一样的，所以每个元素占用的空间大小也是一样的，这样我们就很容易用“数组的开始地址 +index* 元素大小”的计算方式，快速定位到指定索引位置的元素，这也是数组基于下标随机访问的复杂度为 O(1) 的原因。

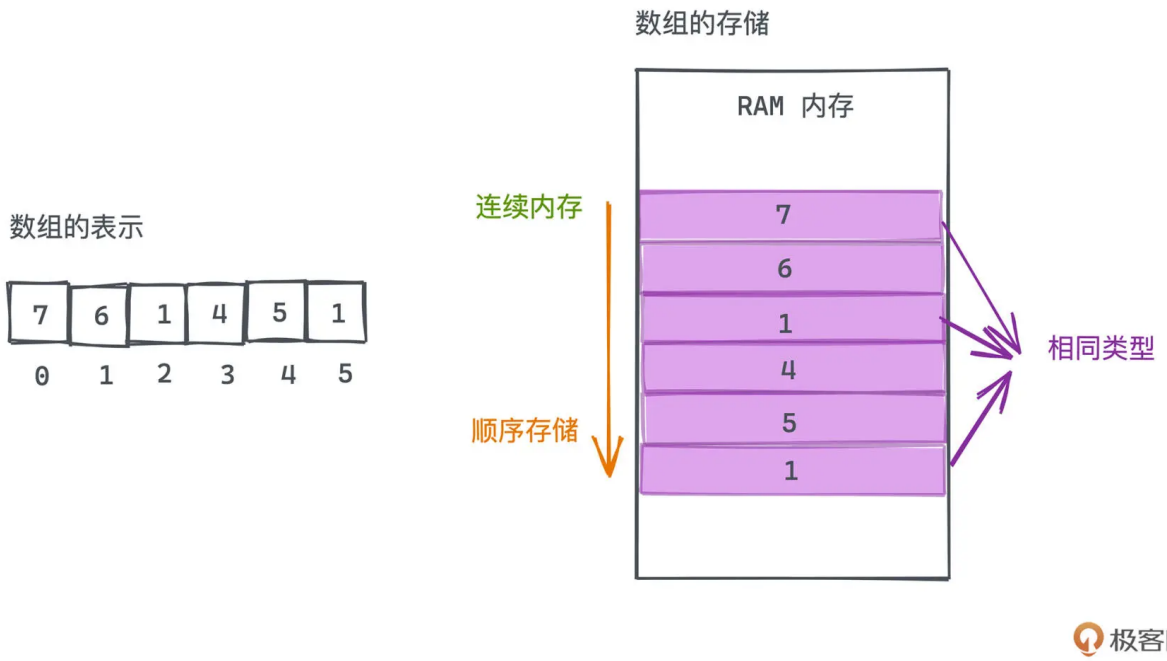

为什么要事先分配一段内存呢？答案也很简单，因为内存空间并不是无限的。一段程序里可能有很多地方都需要分配内存，我们必然要为分配的连续内存寻找一个边界。

事先确定数组大小并分配相应的内存给数组，就是告诉程序，这块地方已经是某个数组的地盘了，就不要再来使用了。同样，访问该数组的时候，下标也不应该超过地盘的范围，在大部分语言里这样的非法操作都会引起越界的错误，但在一些没有越界保护实现的语言（比如 C 语言）中，这就是一个很大的问题，需要开发者非常谨慎。有时这甚至会成为软件被黑客攻击的漏洞。

静态数组的特性

当然，在内存里这样的顺序存储也不是没有代价，这直接导致了数组的插入和删除会低效很多，平均的复杂度是 O(N)。因为数组，和集合不同，**元素在数组中的位置**是我们关心的。

在长度为 N 的数组中，要在下标为 T 的位置插入数据时，原数组中下标为 T 到 N-1 的元素都需要向后顺移一位，这需要遍历数组中共计 N-T 个元素，当然，如果希望插入到数组的末端，只需要做插入而不需要做任何移动操作。但同样，如果我们希望将新元素插入到数组最开始的位置，就要将原数组所有元素都向后移动了，这需要移动共计 N 个元素。

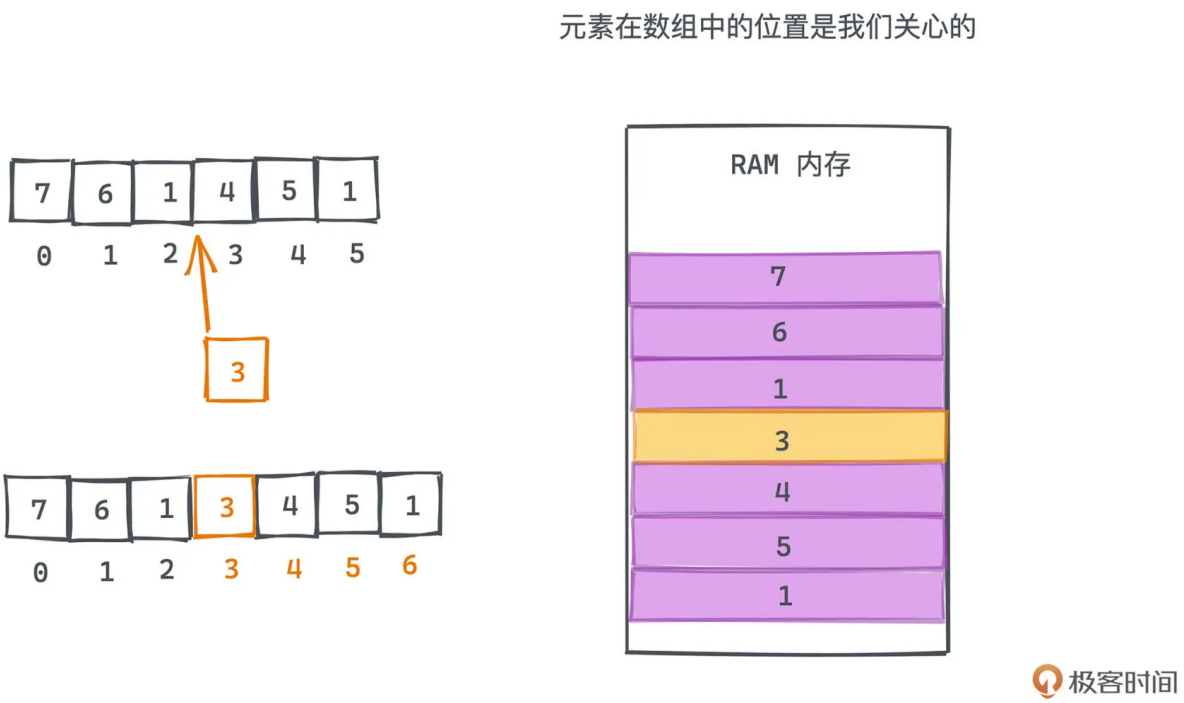

所以平均而言，数组的插入操作的时间复杂度为 O(N)。删除操作基于类似的原因，复杂度当然也是 O(N)。

总的来说，静态数组的特性就是**数组中元素的个数是事先确定的，每个元素都有对应的索引，第一个元素的索引为 0**。因为每个元素在内存占用的空间是一样的，我们可以基于首元素的地址和目标元素的下标，直接定位到目标元素的位置。

动态数组

很显然，使用静态数组的时候需要事先指定空间大小，这并不是很让人们满意。因为静态数组的使用者分配完内存之后，数组空间就不再能扩展（或收缩）了。比如在开头的简易银行系统中，确定固定的数组大小带来的风险就是：当用户数不断上涨直至超过数组容量范围时，我们的系统就不能继续工作了。

唯一的解决方案只能是重新申请一个更大的数组。这个过程，如果自己手动实现，有相当多琐碎的操作，至少包括配置一整块更大的连续内存空间、将元素逐一拷贝至新空间，以及释放原本的空间。

而动态数组的意义就在于将这些繁琐的细节封装起来，给用户良好使用体验的同时，也兼顾效率。这就是为什么我们在大部分业务开发场景下，更多地采用动态数组容器，而不是

原生的静态数组。

STL 的 Vector 就是这样一种经过严格测试和实战检验的动态数组容器，我们下面来分析一下它的原理和实现。其他高级语言的动态数组容器的实现思路其实也是类似的，比如 Java 中的 ArrayList 等（后续我们也会用 Java 中的实现来讲解）。你搞清楚一个，其他的就很好理解了。

动态数组源码分析

当然，STL 的源码涉及了许多高深的 C++ 技巧，我们并不会展开讨论，会对源码做一些简单的调整方便你理解原理。这里也给你一个看源码的小建议，不要死抠细节。我个人看源码比较喜欢**自顶而下的方式，先从大的模块暴露的方法和接口看起，而不是上来就开始研究小模块的实现细节**。

比如学习 STL 源码中 vector 实现的时候，你会经常发现 allocator 相关的方法，如果你揪着它不放一路溯源，会发现 allocator 的底层实现也非常复杂，但是，大多数时候我们不需要这么做，只要理解清楚了 allocator 的哪些方法用来申请内存、哪些方法用于释放内存，具体实现细节暂时当作黑箱，把精力集中在当下要搞清楚的问题上就可以了。

首先，来看 vector 在内存中的表示。它有两个指标，大小和容量。

大小，表示现在存了多少数据。存数据的部分其实和静态数组是一样的，都是一段连续的内存空间顺序排列这若干类型相同、大小一致的元素，但不同的地方在于，数组的大小是可以动态调整的。

我们知道，**向计算机申请空间连续的内存空间是一个成本比较高的操作**，不只需要扫描出堆区内存的空闲内存块，可能还需要向操作系统申请更大的堆空间，并产生用户态 - 内核态的切换成本。

所以为了减少二次分配的次数，初次配置空间的时候，可以分配比 vector 目前所需空间更多一些，后续的若干次插入就不再需要触发昂贵的扩容操作了。这样的可用空间，我们称为 vector 的容量，是 vector 在创建时需要的第二个可选参数。

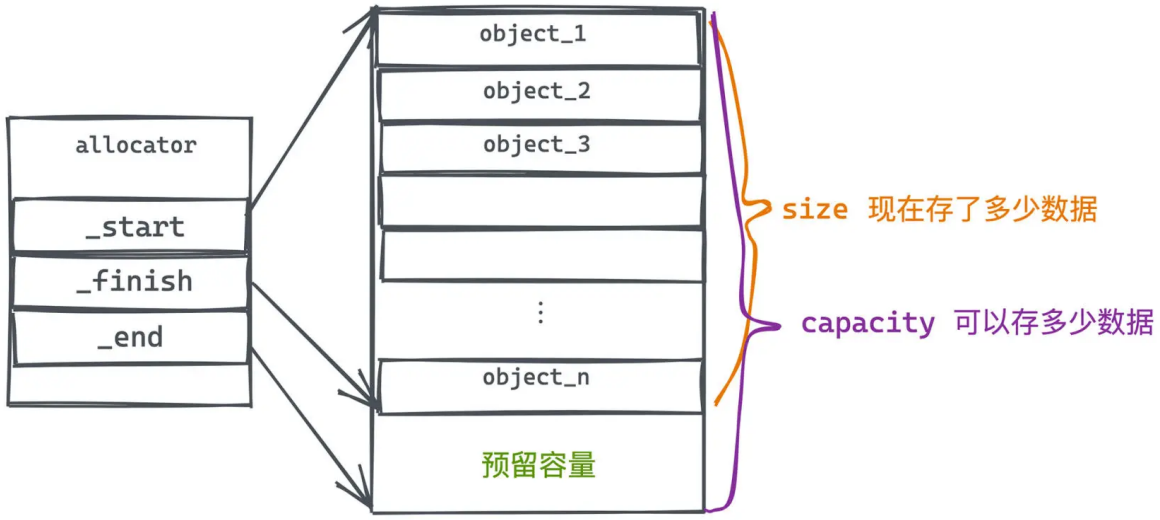

极客时间

所以我们可以用三个指针来标记 vector 空间的使用情况，分别是：

1. _start 指针，指向 vector 第一个元素
2. _finish 指针，指向 vector 最后一个元素
3. _end 指针，指向 vector 预留容量的边界

当然，动态数组的两个核心指标就很容易计算出来了：

1. 容量，capacity = _end - _first，表示目前的数组最多能存储多少个元素
2. 大小，size = _finish - _first，表示数组当前已经存储的元素个数
   对应的代码如下：

复制代码

```
template <class _Tp, class _Alloc = __STL_DEFAULT_ALLOCATOR(_Tp) >
class vector : protected _Vector_base<_Tp, _Alloc>
{
        ...
protected:
  _Tp* _M_start; //表示目前使用空间的头
  _Tp* _M_finish; //表示目前使用空间的尾
  _Tp* _M_end_of_storage; //表示目前可用空间的尾
    ...
```

```
10 };
```

你不用太关注模版相关的语法，只需要知道这里 protected 的三个变量就是前面提到的 3 个指针。

有了这些，我们就可以判断什么时候需要触发扩容操作，以及扩容的方式。因为 vector 创建的时候会给一个容量，但随着我们不断往数组中插入元素，数组的大小终究会超过当前分配的容量，于是需要重新分配更大的内存，那具体分配多少是一个比较合理的值呢？

STL 的扩容方法

来看一下 STL 怎么做的。除了查询已有资料之外，我个人比较推荐动手实验，不仅能随时检验自己脑海里的想法，通过动手实践对原理的理解和印象也更深刻一些。所以我们来编写一些测试方法，观察 Vector 在测试过程中的行为，再和官方文档及资料进行对比验证。

要做的实验也很简单，就是往一个数组里不断的插入元素，并观察 size 和 capacity 的变化。完整的代码可以在这里找到。

复制代码

```
vector<int> v;

for (int i = 0; i < 20; i++) {
    cout << "size: " << v.size() << " capacity " << v.capacity() << endl;
    v.push_back(i);
}
```

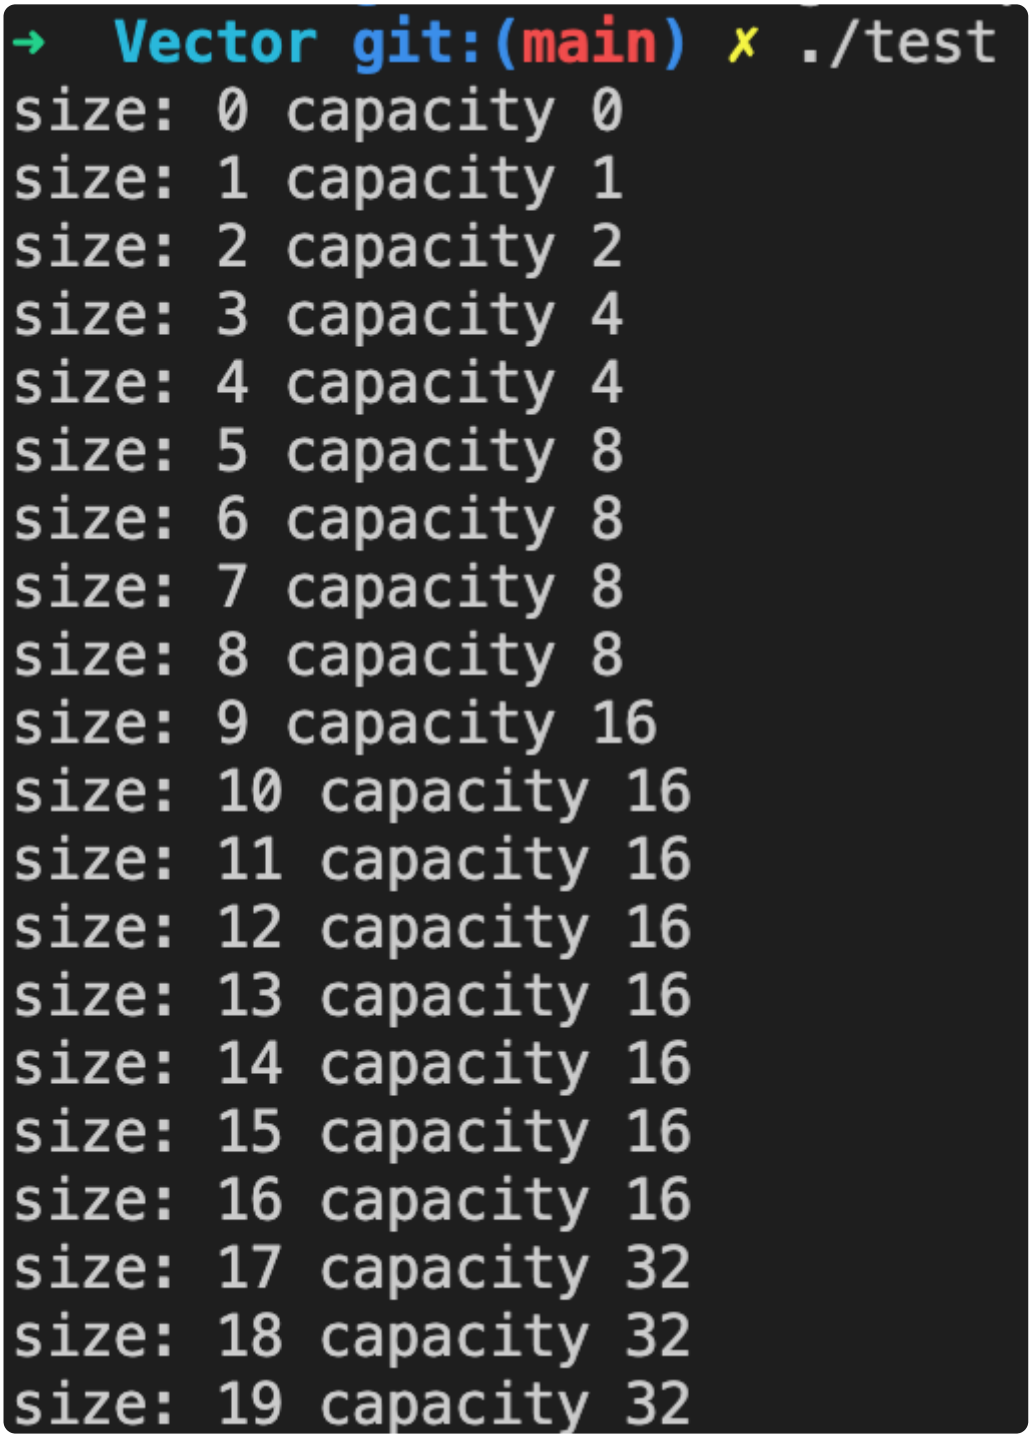

通过实验我们能发现一个很明显的规律：如果每次只插入一个元素，当 vector 的大小小于容量时，容量不会发生变化，数组大小不断递增。而当 vector 的大小即将超过容量的时候，插入之后，容量大小会翻番。

所以，倍增就是 vector 的扩容方式，这种类似倍增的策略也会出现在许多其他使用场景中。

这里很自然会有一个问题，为什么每次扩容时候都是以倍增的方式扩容，而不是增加固定大小的容量呢？

在回答这个问题之前，我们先看一看 STL 扩容逻辑的实现。

复制代码

```
  void push_back(const _Tp& __x) {//在最尾端插入元素
    if (_M_finish != _M_end_of_storage) {//若有可用的内存空间
      construct(_M_finish, __x);//构造对象
      ++_M_finish;
    }
    else//若没有可用的内存空间,调用以下函数，把x插入到指定位置
      _M_insert_aux(end(), __x);
  }

template <class _Tp, class _Alloc>
  void
  vector<_Tp, _Alloc>::_M_insert_aux(iterator __position, const _Tp& __x)
  {
    if (_M_finish != _M_end_of_storage) {
      construct(_M_finish, *(_M_finish - 1));
      ++_M_finish;
      _Tp __x_copy = __x;
      copy_backward(__position, _M_finish - 2, _M_finish - 1);
      *__position = __x_copy;
    }
    else {
      const size_type __old_size = size();
      const size_type __len = __old_size != 0 ? 2 * __old_size : 1;
      iterator __new_start = _M_allocate(__len);
      iterator __new_finish = __new_start;
      __STL_TRY {
        __new_finish = uninitialized_copy(_M_start, __position, __new_start);
        construct(__new_finish, __x);
        ++__new_finish;
        __new_finish = uninitialized_copy(__position, _M_finish, __new_finish)
      }
      __STL_UNWIND((destroy(__new_start,__new_finish),
                    _M_deallocate(__new_start,__len)));
      destroy(begin(), end());
      _M_deallocate(_M_start, _M_end_of_storage - _M_start);
      _M_start = __new_start;
      _M_finish = __new_finish;
      _M_end_of_storage = __new_start + __len;
    }
  }
```

这段扩容操作在 push_back 和 insert 操作中都会触发，我们以简单一点的 push_back，也就是往数组尾部插入元素的操作为例，来解释扩容的逻辑。

可以看到，push_back 的时候会先做一个判断，看当前的容量是不是不够用了。如果够用，我们只要直接往后插入一个元素；**不够用，才进行 _M_insert_aux 扩容并插入的操作，插入后需要把 finish 指针往后移动**。这里在容量够用的时候，插入逻辑用的是 construct 函数，是 STL 容器中通用的构造方法。

我们来重点分析扩容逻辑所在的 _M_insert_aux 方法：

13-20 行，实际上是因为还有其他函数会调用这个方法，我们已经确定容量不足，所以不会进入这段逻辑。

22-25 行，主要做的事情就是读取原有的 vector 大小 old_size，再从内存里申请一段新的空间，大小为 2*old_size，创建新的首尾指针并指向新的空间。

26-31 行，将老空间里的数据逐一搬到新的空间里，并在最后添加新的元素。这样就完成了扩容的主要目的，这是一个 O(n) 复杂度的操作，因为你需要对原数组进行逐一的深拷贝。

最后，在 32-38 行，我们需要做一些清理和收尾工作，释放掉老的数组空间和指针，将容器的首尾及容量指针都更新到对应的位置。

这样 Vector 就完成了对扩容操作的封装，是不是其实并不复杂呢？

现在清楚扩容的具体实现之后，来解答前面的问题：为什么扩容是采用倍增的方式，而不是每次扩展固定大小？这背后其实是有严密数学依据的，非常有趣，我们一起来探索一下。

用极端法来考虑这个问题。

先假设是不是可以不倍增，而是每次只扩展一个元素呢？直觉上这当然是不合理的，这会导致每一次插入都会触发扩容，而每次扩容都会进行所有元素的复制操作。所以如果我们要插入 n 个元素，需要进行的拷贝次数：

$$1 + 2 + 3 + \ldots + n = n^2$$

复杂度为 O(n^2)，均摊下来每次操作时间复杂度就是 O(n)。

那如果我们不是每次只拓展一个元素，而是每次扩展 C 的容量，对复杂度的计算会产生多大的影响呢？同样来计算一下，每插入 C 次就需要进行一次扩展操作，每次扩展仍然需要复制全部元素，所以总的拷贝次数是：

$$C + 2C + 3C + \ldots + floor(n/C) = n^2$$

复杂度同样为 O(n^2) 。均摊下来每次操作时间复杂度还是 O(n)。 虽然次数少了 C 倍，但仍然不令人满意。

更好的做法就是和 STL 一样采用倍增的思想，每次都将容量扩展为当前的一倍，它往往能让我们的时间复杂度下降很多。

算一下倍增这种策略下需要拷贝的次数：假设一共还是插入 N 次，那总拷贝次数，就是从 1 加到 2 的 X 次，其中 x 是 logn 向上取整；这是因为容量每次都在翻番，所以每次触发拷贝的时候，容量分别是 1、2、4、8 ... 一直到 logn 向上取整。

$$1 + 2 + 4 + 8 + \ldots + 2^x = 2^{(x+1)} - 1$$

这样插入 N 个元素的复杂度就一下减少为 O(N) 了。均摊到每次插入的扩容复杂度就为 O(1)，这当然是一个令人满意的结果啦。

总结

相信经过今天的学习，你一定已经对开头的几个问题有答案了吧，简单总结一下。数组，是支持 O(1) 基于下标随机访问的数据结构，在内存中是连续存储的。基于下标高效访问元素的核心就在于“相同类型”和“连续存储”的特性，当然，也带来了高昂的插入和删除的时间复杂度。

动态数组之所以能看起来像是无限容量，也仅仅是因为它内置了倍增的扩容策略，每次数组大小超过容量的时候，就会触发数组的扩容机制，封装了繁琐的拷贝细节。

也正是因为上述特性，动态数组广泛应用在需要经常查询、变更，但是很少插入 / 删除的场景，比如我们在实现一个简单的 Web 服务器的时候，可以用 vector 来存储 handler 的线程，达到线程复用的效果。

你应该感受到了今天的内容比上一讲的文本差分要简单一些，是的，**接下来我们会先把数据结构实现的基础打好，了解清楚背后的实现原理**，这样在日常开发中，不同的数据结构可能造成什么样的性能瓶颈，你都能烂熟于心。

课后作业

我们已经细致地分析了在 vector 中插入元素的方法，如果要删除一个元素应该怎么实现呢？在删除元素的时候需不需要缩容呢？如果需要的话，你会怎么做。

这是一个开放问题，欢迎你在留言区与我讨论。我们下节课见。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 先导篇 | 诶，这个 git diff 好像不是很直观？

下一篇 02 | 双向链表：list如何实现高效地插入与删除？

精选留言 (12)

写留言

2021-12-12

在 Java 的 ArrayList 中，没有自动缩容，但是提供了一个 trimToSize() 的方法可以让使用者手动缩容；如果要设计自动缩容的话，可以简单设计成 size 减少到到 capacity/4 的时候，将容量缩减成原来的一半

展开

作者回复: 哈哈哈 学到了~

2

Paul Shan
2021-12-13

如果在存储空间占比低于一半的时候就缩容，会导致反复插入删除回到单步操作O(n)的复杂度，以前见过的实现是存储的空间占总空间的1/4的时候开始缩容一半，可以做到单步均摊复杂度O(1)。数组看似简单，实则精妙，平均浪费一半空间的时候，才能取得较好的性能，也算一种空间换时间的方法。

展开

作者回复: 嗯嗯 设计就是在不断的权衡中一步步优化的

1

qinsi
2021-12-15

两倍扩容的问题在于无法利用已释放的空间，因为假设第n次扩容分配了2^n的空间（省略常数C），那么之前释放掉的空间总和为：

1 + 2 + 2^2 + ... + 2^(n-1) = 2^n - 1

...

展开

奋青。
2021-12-15

所以如果我们要插入 n 个元素，需要进行的拷贝次数：1+2+3+...+n=n2复杂度为 O(n^2)，均摊下来每次操作时间复杂度就是 O(n)。 这句话里面的 o(n^2) 是怎么计算得到的呀.

作者回复: 就是小学二年级学过的等差数列求和哦

2021-12-14

自己总结一下：按照1扩容 那么 1+2+3+4 > 8 其实越往后拷贝的越来越多 每次扩容要拷贝的越来越多，但是之前我疑惑我把数值调大不就行了吗，第一浪费空间不说，可以继续算一下从1->4 那么每次就是 1+5+9+13+17+21+25 扩容到25需要6次,如果是按1扩容那么就是24次 那么就是减少了C倍而已 当数值越来越大 在 扩容到17的时候应该复杂度就上

去了 如果是翻倍扩容 那么 公式就是 1 + 2 + 4 ... +n < 2*n 均摊下来扩容就是O（1）...

展开

作者回复: 说的没错 主流动态数组的实现都是倍增的策略哦

kimoti

2021-12-14

看完这节感觉可以不至于从入门到放弃

展开

作者回复: 加油加油 https://github.com/wfnuser/Algorithms 可以多多尝试自己手写实现～

DaveZ

2021-12-14

扩展C那里，平均应该是O(n)而不是O(1)

展开

编辑回复: 是的是的，已经修改过来啦

Dreamer

2021-12-13

自动代表不可控，线上很多时候，cpu资源和内存资源，更关注cpu资源多一些，其次缩容的阈值不好定。

展开

作者回复: 嗯嗯 不同业务场景都需要有不同的考虑

Aliliin

2021-12-13

go 语言中提供的 slice 是不是就是动态数组呢，定义的时候，长度并不固定，可以向切片

中追加元素，它会在容量不足时自动扩容。也提供了 len 和 cap 函数来获取长度和容量。当然 go 中的 slice 扩容的方案，不是倍增的方式，而是他自己的算法，小于 1024 才会将容量翻倍，大于 1024 每次只是增加 25% 的容量。但 go 的 slice 扩容之后，会新申请一段内存，拷贝过去，你即便删除了扩容的部分，内容大小也不会变。这时候，因为你是...

展开

作者回复: 哈哈哈 总结的不错呀 对golang不是特别熟悉；学到了～

共 3 条评论

雷霹雳的爸爸

2021-12-13

缩容这个我个人感觉是，可以有，但是不要搞什么自动缩...因为删除这个操作和增加这个还真不一样，增加时候满了你不扩就玩儿不转了，因此自动扩容属于必须要实现的能力吧，要不我自己直接用数组不就完事了，但是删除不自动缩更合理，参考本文讲解的每次扩容就加一那个脑补一下就很容易理解了，至于那是不是低到一定水位就可以执行自动缩？这个应该也不能这么玩儿，一个是缩了之后留多少空位的问题，更重要的还是这个...

展开

作者回复: 这位同学说的很对。 其实，很多动态数组实现就是支持缩容操作的。
不过自动缩容在绝大多数场景里意义不大；所以相关的实现比较少。

Geek_as

2021-12-12

java的arraylist的扩容策论是增加原有容量的一半，即容量为10，扩容就为5，arraylist在做删除的时候我记得是调用了jdk提供的api将删除节点的后面往前面移动。假如让我来实现，我可能考虑的是这个数组是否需要保证插入顺序，假如不用的话，可能用数组最后的数来替换删除数

展开

作者回复: 嗯嗯 你说的这种做法也是力扣上的某道算法题的解
不过在用数组的很多时候，我们都是需要维护数组的顺序的哦

qinsi

2021-12-11

真实世界的算法，远不是时间复杂度这么简单。考虑到最大化利用已释放的内存，最优的扩容比率是1.618

展开

作者回复: 哈哈哈 这个能具体讲一下嘛 听起来好像有点厉害～